

Evaluación de la viabilidad de un modelo de Machine Learning para el análisis de sentimiento en la categoría calzado de descanso en Mercado Libre Colombia mediante Web Scraping

Elaborado por:
Carlos Mauricio Arteaga Bermúdez
María Alejandra Olarte Delgado
Joaquín Eduardo Perdomo Artunduaga
Lina Rocío Quitian Zaza

Universidad EAN
Seminario de Investigación de Pregrado
Bogotá

Tabla de Contenido

Resumen	5
Planteamiento del Problema	5
Objetivos	8
General.....	8
Específicos.....	8
Justificación.....	9
Marco Teórico.....	10
Comercio electrónico y marketplaces	10
Importancia de la percepción del consumidor en marketplaces	11
Análisis de sentimiento en comercio electrónico.....	13
Aplicación de Machine Learning y Procesamiento del Lenguaje Natural (NLP).....	14
Marco institucional	18
Enfoque, alcance y diseño de la investigación.....	20
Definición de variables.....	21
Población y Muestra	23
Metodología de la investigación.....	24
Selección de métodos para recolección de información.....	28
Técnicas de análisis de datos	29
Análisis y discusión de los resultados	30
Resultados descriptivos	30
Resultados del modelo	40
Conclusiones	48
Referencias.....	53

Lista de Tablas

Tabla 1 Variables Principales	21
Tabla 2 Variables de Contexto	22
Tabla 3 Modelos Entrenados	41

Lista de Figuras

Figura 1 Flujo del proyecto de ML para análisis de sentimientos.....	26
Figura 2 Nube de palabras de las descripciones	31
Figura 3 Histograma cantidades vendidas por producto	32
Figura 4 Gráfico de dispersión entre la cantidad vendida y el número de calificaciones por producto.....	32
Figura 5 Histograma de calificaciones de los productos	33
Figura 6 Nube de palabras de los comentarios	34
Figura 7 Frecuencia de principales bigramas de los comentarios de productos calificados con 4 y 5 estrellas.....	35
Figura 8 Frecuencia de principales bigramas de los comentarios de productos calificados con 3 estrellas	36
Figura 9 Frecuencia de principales bigramas de los comentarios de productos calificados con 2 y 1 estrellas.....	36
Figura 10 Top de vendedores por número de productos	38
Figura 11 Top de vendedores por cantidad de productos vendidos.....	39
Figura 12 Top de vendedores por volumen de ventas.....	39
Figura 13 Reputación del vendedor.....	40
Figura 14 Comparativo de las métricas modelos ML con mayor desempeño	43

Figura 15 Distribución de probabilidades.....	44
Figura 16 Matriz de confusión	45
Figura 17 Curva ROC.....	46
Figura 18 Matriz de confusión	47
Figura 19 Curva ROC.....	48

Resumen

Este estudio explora el potencial de la inteligencia artificial para comprender las percepciones de los compradores sobre productos adquiridos en línea, con un enfoque específico en la categoría de calzado de descanso (pantuflas, chanclas, sandalias) en Mercado Libre Colombia. Hoy en día, los compradores no solo adquieren productos en línea, también dejan comentarios y reseñas que reflejan su experiencia. Esta enorme cantidad de opiniones se ha convertido en una fuente valiosa de información para las marcas. Sin embargo, procesarla manualmente es un desafío y donde herramientas como el *Web Scraping*, el *Machine Learning* (ML) y el *Procesamiento de Lenguaje Natural* (NLP) se vuelven importantes, ya que permiten recopilar y analizar automáticamente lo que los clientes sienten y opinan sobre los productos.

Se recolectaron más de 2.700 productos y cerca de 4.700 comentarios reales de clientes. Después de filtrar y organizar esos datos, se aplicaron varios modelos de inteligencia artificial para identificar si los comentarios eran positivos o negativos. Los modelos más destacados fueron CNN Ensemble y LSTM ensemble, ofreciendo un balance entre precisión y capacidad para detectar opiniones negativas sin caer en errores frecuentes. Los hallazgos mostraron que la mayoría de los comentarios son positivos, pero que los comentarios negativos tienden a ser más detallados. Así mismo, se identificó que las calificaciones de 3 estrellas, las cuales se tomarían como neutrales, en realidad suelen reflejar insatisfacción. También se observó que los productos más vendidos tienden a ser los menos costosos. El estudio confirma que es viable aplicar modelos de ML para entender cómo se sienten los clientes y analizar la dinámica de mercado. Esta información puede convertirse en una herramienta poderosa para mejorar la experiencia de compra, fortalecer la reputación de marca y tomar decisiones comerciales más acertadas.

Palabras clave: inteligencia artificial, análisis de sentimientos, calzado de descanso, Mercado Libre, procesamiento de lenguaje natural, machine learning, reseñas de usuarios, comercio electrónico

Planteamiento del Problema

El comercio electrónico ha transformado la manera en que las empresas y los consumidores interactúan en el mercado digital. Definido como un ecosistema donde se llevan a cabo actividades de compra y venta de productos y servicios a través de internet (Asociación Española de la Economía Digital, 2012), este modelo ha crecido exponencialmente gracias al desarrollo de herramientas tecnológicas que garantizan transacciones más seguras y eficientes. Todo esto ha desembocado en una nueva realidad, un cambio de paradigma, donde los modelos y actividades comerciales cambian a diario alrededor del mundo y donde las nuevas tecnologías y la inteligencia artificial se convierten en medios en los que se sustentan la revolución de comprar por internet (Cumming et la., 2023). En Colombia, el comercio electrónico se ha consolidado como un motor clave del desarrollo empresarial, impulsado en gran parte por la pandemia de COVID-19, que aceleró su adopción y generó nuevas oportunidades de expansión (Vargas, 2020).

La Cámara Colombiana de Comercio Electrónico (2023), ha revelado cifras sobre el desarrollo de del mercado virtual o Marketplace en Colombia donde en 2023 evidencia una cifra de 55 billones en transacciones digitales, mostrando así un incremento del 38,4% con respecto al año anterior y en 94% con respecto al año 2020. Llevado la mayor participación la industria de la moda y belleza. Esto demuestra un gran crecimiento en la economía de los e-commerce en el país.

Uno de los sectores beneficiados, en Colombia, por esta transformación digital ha sido el del calzado de descanso, que incluye pantuflas, babuchas, sandalias y chanclas. Durante la pandemia, la demanda de este tipo de productos aumentó significativamente, ya que las personas pasaban más tiempo en casa y priorizaban la comodidad; según la Asociación Colombiana de Industriales del Calzado, el Cuero y sus Manufacturas (Acicam), el calzado de descanso representó el 75% de las ventas de calzado en 2020. Además, este nicho de mercado

también utiliza plataformas digitales como Mercado Libre, facilitando las ventas y distribución a nivel nacional (Pérez, 2021).

A pesar de su crecimiento, este ecosistema presenta desafíos significativos, especialmente en la gestión y análisis de la percepción de los consumidores. La creciente cantidad de opiniones y reseñas generadas diariamente en plataformas como Mercado Libre dificulta la identificación de patrones de satisfacción e insatisfacción, lo que limita la capacidad de las marcas para comprender las necesidades de los clientes y mejorar sus estrategias de mercado (Harunasir et al., 2023). La falta de un análisis estructurado de las opiniones de los consumidores impide a las empresas optimizar su oferta y fortalecer su posicionamiento en el mercado digital.

Si esta situación persiste, las empresas seguirán perdiendo oportunidades de mejorar la experiencia del cliente y de fortalecer su reputación en línea, lo que podría afectar negativamente su competitividad en el comercio digital. Sin una herramienta efectiva para analizar grandes volúmenes de reseñas, los vendedores de calzado de descanso en plataformas digitales como Mercado Libre corren el riesgo de no responder adecuadamente a las expectativas de los consumidores, lo que podría derivar en una disminución en la confianza y lealtad de los clientes.

Para abordar esta problemática, el uso de técnicas avanzadas como Web Scraping y Machine Learning ofrece una solución viable. Estas herramientas permiten la extracción automatizada de datos y el análisis de sentimientos en reseñas de clientes, proporcionando información valiosa para la toma de decisiones estratégicas (Geetha & Renuka, 2021). La aplicación de estos modelos en el sector del calzado de descanso facilitaría la identificación de tendencias de consumo, la optimización de productos y el fortalecimiento de la percepción de marca en plataformas de comercio electrónico.

En este contexto, resulta fundamental comprender de qué manera el análisis de sentimiento basado en Web Scraping y Machine Learning puede contribuir a identificar la percepción de marca en la categoría de calzado de descanso en Mercado Libre Colombia, así como los patrones de consumo que pueden extraerse de las opiniones de los clientes para mejorar la toma de decisiones estratégicas.

Objetivos

General

Evaluar la viabilidad de un modelo de Machine Learning para el análisis de sentimiento en la categoría de calzado de descanso de Mercado Libre Colombia, a partir de datos obtenidos mediante Web Scraping, con el fin de identificar tendencias en las opiniones de los clientes y aportar información para la toma de decisiones.

Específicos

1. Extraer datos de reseñas, preguntas y comentarios de productos de calzado de descanso en Mercado Libre Colombia mediante Web Scraping.
2. Aplicar técnicas de Procesamiento de Lenguaje Natural (NLP) para identificar patrones recurrentes en las opiniones de los clientes sobre calzado de descanso en Mercado Libre Colombia.
3. Implementar un modelo de Machine Learning para analizar el sentimiento a partir de los datos extraídos.
4. Proponer recomendaciones estratégicas para vendedores en función de los hallazgos obtenidos del análisis de sentimiento.

Justificación

El análisis de sentimiento y percepción de marca en Mercado Libre Colombia representa una potencial herramienta para los vendedores de calzado de descanso, permitiéndoles comprender la experiencia del usuario más allá de las métricas tradicionales de ventas. Actualmente, muchas decisiones comerciales se toman sin considerar las opiniones y emociones expresadas en reseñas y preguntas dentro de la plataforma, lo que genera una oportunidad para optimizar estrategias de producto y marketing (Espitaleta et al., 2022).

Esta investigación ofrece un enfoque que combina Web Scraping y Machine Learning para la extracción y análisis de datos de consumidores. Esto permitirá a los vendedores identificar tendencias, detectar oportunidades de mejora y fortalecer su posicionamiento dentro del marketplace, lo que impactará directamente en la competitividad de sus productos. Al analizar el sentimiento del consumidor, se pueden identificar factores clave para mejorar la relación con los clientes, fomentar la fidelización y contribuir a un comercio electrónico más transparente y eficiente.

Además, conocer sobre el impacto del análisis de sentimiento en el comercio digital podría ser una estrategia que aumente la capacidad de las empresas para aprovechar su potencial de ventas. Esta investigación aportará un marco conceptual basado en la aplicación de inteligencia artificial para evaluar la viabilidad del análisis de reseñas en plataformas de comercio electrónico con el fin de ampliar el conocimiento sobre el comportamiento del consumidor en entornos digitales.

Por último, esta investigación ofrecerá un modelo que podría ser replicable para otras categorías de productos y sectores dentro de Mercado Libre y otras plataformas similares. Al proporcionar la evaluación de un método basado en datos para comprender la percepción de

marca y las tendencias de consumo, se contribuirá al desarrollo del comercio electrónico basado en inteligencia artificial y análisis de datos en Colombia.

Marco Teórico

Comercio electrónico y marketplaces

El comercio electrónico ha transformado la manera en que empresas y emprendedores se conectan con sus clientes, permitiendo ampliar el alcance y mejorar la visibilidad de sus productos. En este contexto, los marketplaces juegan un papel clave al ofrecer espacios digitales donde compradores y vendedores interactúan y realizan transacciones. Por ejemplo, la CEPAL (2020), destaca en sus análisis la importancia de la digitalización para superar barreras geográficas y sociales, lo que permite a los consumidores acceder de forma rápida y segura a una amplia variedad de productos desde la comodidad de su hogar.

Dentro de este ecosistema, Mercado Libre se ha consolidado como una de las plataformas de comercio digital más importantes en Colombia. Un informe de Kantar (2022) señala que el segmento de retail media ha crecido considerablemente en la región, posicionando a Mercado Libre como líder en inversión publicitaria y en la aceptación de los usuarios. Además, estudios publicados en el portal de Mercado Libre indican que, a nivel latinoamericano, un alto porcentaje de consumidores utiliza la plataforma para comparar precios y descubrir nuevos productos (Mercado Libre, 2023).

El crecimiento del comercio electrónico no se limita a una región en particular, sino que es un fenómeno global impulsado por la masificación de internet y el auge de las tecnologías móviles. La OECD (2019), destaca que estas innovaciones han permitido a las pymes optimizar sus procesos logísticos y de distribución. Asimismo, en su libro *Marketing Management*, Kotler y Keller (2016), explican cómo la adopción de canales digitales ha llevado a las empresas a evolucionar desde modelos tradicionales hacia estrategias más integradas y diversificadas.

Por otro lado, los marketplaces se han vuelto el corazón del ecosistema digital al reunir a múltiples vendedores y compradores en un solo espacio virtual. Un informe de EBANX (2021) sobre el comercio electrónico en América Latina describe cómo estas plataformas actúan como intermediarios confiables, ofreciendo sistemas de pago seguros y fomentando la confianza a través de valoraciones y reseñas. De igual forma, eMarketer (2021), resalta que estos entornos digitales reducen las barreras de entrada para nuevos vendedores y minimizan los costos de búsqueda para los consumidores, lo que favorece una mayor competencia y diversidad en la oferta.

En la actualidad, la principal ventaja competitiva de un negocio que opera en marketplaces radica en su capacidad para adaptarse a un entorno en constante cambio y centrado en la experiencia del cliente. La OECD (2019), enfatiza que la transformación digital obliga a las empresas a reinventar sus modelos de negocio y ajustar sus estructuras organizativas. Asimismo, Kotler y Keller (2016), subrayan la importancia de fomentar una cultura de innovación e integrar de forma eficiente estrategias de marketing, logística y tecnología para garantizar la sostenibilidad en el ámbito digital. Todo ello refuerza el papel central de plataformas como Mercado Libre en el escenario del comercio electrónico contemporáneo.

Importancia de la percepción del consumidor en marketplaces

En los entornos digitales, la confianza del consumidor es un factor determinante en la decisión de compra. Las reseñas y comentarios de los clientes desempeñan un papel fundamental en la percepción de la calidad y confiabilidad de los productos y vendedores. Además, el crecimiento de la comunicación entre los consumidores a través de canales como blogs, redes sociales y otras plataformas ha facilitado un mayor contacto entre empresas y clientes.

Vij y Kaur (2024), en su estudio sobre la percepción de los consumidores hacia el comercio electrónico, identifican los factores más relevantes que pueden influir en esta percepción. En primer lugar, destacan la satisfacción y la promoción; según los autores, el éxito de un negocio depende en gran medida de la satisfacción y el respaldo de los clientes. La experiencia del usuario, la calidad del producto y una atención al cliente adecuada, son elementos clave que contribuyen a la satisfacción.

Cuando los clientes están satisfechos, generan un voz a voz positivo, ya sea a través de la plataforma de comercio o mediante redes sociales, lo que actúa como una forma de promoción. En este sentido, la satisfacción y la promoción están estrechamente relacionadas: los clientes satisfechos tienden a dejar comentarios positivos, lo que a su vez atrae a nuevos compradores. Muchas decisiones de compra se ven influenciadas por este valor social, directamente vinculado al respaldo de otros consumidores y sus opiniones como es mencionado por los autores.

Es importante reconocer el papel que juegan los medios sociales en las dinámicas del comercio electrónico, lo que ha dado lugar al concepto de comercio social (S-commerce). Este modelo incrementa la interactividad social a través de la interacción entre comunidades y entre vendedores y compradores. Como explica Stephen (2010), el comprador asume un rol adicional que puede ir desde la generación de contenido, comentarios y reseñas hasta convertirse en vendedor o curador de tiendas en línea.

Al igual que los autores anteriormente citados, este autor plantea que las compras sociales están estrechamente vinculadas al voz a voz en línea. Desde la perspectiva del comprador y del vendedor, la percepción juega un papel clave, ya que la influencia generada por los consumidores impacta directamente en la imagen de las marcas y en los resultados de una empresa. Además, el contagio social dentro de los medios digitales refuerza la confianza y facilita la difusión de productos o servicios. Sin embargo, cuando un producto tiene una alta demanda y

acumula grandes volúmenes de reseñas, analizar esta información de manera eficiente se convierte en un desafío para los vendedores.

Los consumidores suelen expresar tanto opiniones positivas como críticas dentro de la misma sección de comentarios, lo que permite identificar patrones de satisfacción e insatisfacción. En general, las reseñas con calificaciones de cuatro o cinco estrellas son consideradas positivas, mientras que aquellas con una o dos estrellas reflejan una percepción negativa del producto. No obstante, incluso dentro de valoraciones altas, los clientes pueden incluir observaciones sobre posibles mejoras o inconvenientes con el producto (Harunasir et al., 2023).

Análisis de sentimiento en comercio electrónico

Bing Liu (2020), en su libro *Sentiment Analysis Mining Opinions, Sentiments, and Emotions*, define el análisis de sentimientos, también conocido como minería de opinión, como “un campo de estudio que se centra en el análisis de las opiniones, emociones y actitudes de las personas expresadas en textos” (p.1).

En el contexto del comercio electrónico, el análisis de sentimientos ha surgido como una herramienta esencial para comprender la percepción del cliente. Los consumidores evalúan productos o servicios basándose en distintos criterios, como especificaciones, anuncios o reseñas. Estas últimas, en particular, son uno de los factores más influyentes en las decisiones de compra, ya que ayudan a reducir el temor a ser estafado y fortalecen la confianza entre consumidores y empresas (Saraswat et al., 2022).

Para las empresas, el análisis de sentimientos ofrece una ventaja competitiva al permitir la identificación de tendencias, la detección de problemas recurrentes y la mejora de la experiencia del usuario. Al aplicar modelos de análisis de sentimientos en las reseñas de productos, las compañías pueden anticiparse a problemas potenciales, optimizar sus estrategias

de marketing y mejorar su posicionamiento en el mercado (Daza et al., 2024). Asimismo, esta técnica facilita la identificación de patrones en los comentarios de los clientes, lo que permite tomar decisiones estratégicas informadas (Geetha & Renuka, 2021).

Además, el análisis de sentimientos basado en la minería de texto permite predecir el tipo de reseña y la experiencia del producto, así como determinar la calidad de un servicio sin necesidad de leer todas las reseñas. En un entorno donde existen múltiples productos similares, el análisis manual de cada reseña puede ser un proceso largo y complejo; sin embargo, el uso de estas técnicas agiliza la toma de decisiones y ayuda a seleccionar la mejor opción disponible (Saraswat et al., 2022).

Una de las técnicas que permite extraer grandes cantidades de información, facilitando la recuperación de registros, incluyendo las reseñas de las páginas de e-commerce y el monitoreo de internet es Web Scraping. Es una técnica rápida y eficiente comparada con la extracción manual de datos. Su capacidad para acceder a grandes volúmenes de datos en línea de manera rápida y sencilla lo convierte en una herramienta clave, en diferentes industrias, donde la retroalimentación del cliente es esencial para evaluar productos y campañas (Kaur, 2022).

El Web Scraping, combinado con métodos de Procesamiento del Lenguaje Natural (NLP), no solo permite extraer grandes volúmenes de datos, sino también analizarlos de manera rápida y eficiente. Esta sinergia optimiza el análisis de sentimientos en sitios web, facilitando la obtención de información estratégica para la toma de decisiones, especialmente en contextos donde la retroalimentación del cliente y su frecuencia son clave.

Aplicación de Machine Learning y Procesamiento del Lenguaje Natural (NLP)

La inteligencia artificial (IA) se ha convertido en un tema de gran relevancia en la actualidad. El procesamiento de lenguaje natural (NLP, por sus siglas en inglés Natural Language Processing), se encuentra estrechamente relacionado con este concepto, dado que es un área

de estudio derivada de la inteligencia artificial y también de la lingüística que busca estudiar cómo se comunican los seres humanos y las máquinas a través del lenguaje natural (Cortés Díaz, 2021).

El Procesamiento del Lenguaje Natural ha demostrado ser una herramienta fundamental en el análisis de sentimiento, ya que permite la interpretación y análisis de texto no estructurado. Empresas de comercio digital han incorporado modelos basados en NLP para mejorar la segmentación de clientes, desarrollar estrategias de mercado más precisas y fortalecer la reputación de sus productos y marcas en entornos digitales (Elastic, s.f.). El procesamiento del lenguaje natural se utiliza para identificar la polaridad de los comentarios o reseñas que los usuarios dejan.

A su vez, el Machine Learning (ML) o aprendizaje automático es también un área de estudio de la inteligencia artificial que busca que las máquinas aprendan de datos generados, ya sea de fuentes humanas o artificiales, para realizar una tarea específica a partir de la experiencia. Dentro de las aplicaciones más comunes del ML encontramos la predicción de tendencias, la clasificación de datos y el análisis de texto (Espitaleta et al., 2022), esta última de principal importancia para la presente investigación.

El Machine Learning permite la automatización de tareas que a un humano podría tomarle horas o tal vez días, a través de algoritmos que aprenden de datos históricos y buscan generar predicciones. Acorde al libro *Deep Learning for NLP and Speech Recognition* de Kamath et al., (2019), los principales enfoques del Machine Learning pueden dividirse en:

Aprendizaje supervisado: Sucede cuando el aprendizaje se da a partir de datos procesados que contienen etiquetas, es decir, valores o categorías asignados que indican el resultado esperado. Estas etiquetas actúan como una “respuesta correcta” que el modelo debe aprender a predecir. Hay dos tipos principales de aprendizaje supervisado; el primero es la

clasificación, donde se busca categorizar un valor específico dentro de una clase, por ejemplo, y para efectos de nuestra investigación, predecir si un comentario es positivo o negativo; el segundo es la regresión que consiste en intentar predecir un valor futuro dado un grupo de variables dentro de un rango esperado, por ejemplo, pronosticar las ventas de un producto para un periodo de tiempo específico.

Aprendizaje no supervisado: Se relaciona con conjuntos de datos que no han sido etiquetados previamente ni pertenecen a categorías predefinidas. Para este enfoque, el algoritmo busca identificar agrupaciones o patrones característicos entre los elementos que presentan similitudes. Un ejemplo sería analizar un conjunto de datos que describa a usuarios según las películas que han visto y disfrutado, para luego agruparlos en diferentes *clusters* en función de sus comportamientos.

Aprendizaje semi-supervisado y aprendizaje activo: Tiene un enfoque intermedio entre el aprendizaje supervisado y no supervisado, en este algoritmo se tiende a trabajar con conjuntos de datos en los que solo una parte ha sido etiquetada y la gran mayoría no lo está. Por otro lado, el aprendizaje activo es cuando la máquina es capaz de identificar datos relevantes y requiere la intervención del humano para su etiquetado.

Aprendizaje por transferencia y aprendizaje multitarea: El aprendizaje por transferencia es cuando tomamos un modelo que ya ha sido entrenado para una tarea específica y lo reutilizamos ajustándolo para una nueva tarea, aprovechando así ese entrenamiento previo, y a su vez el aprendizaje multitarea es aprovechar el modelo entrenado previamente para realizar varias tareas relacionadas al mismo tiempo y que el modelo se compartimenta para hacer mejor el trabajo asignado.

Aprendizaje por Refuerzo: Es cuando el aprendizaje se da basado en un sistema de recompensas, es decir, la intervención humana o un sistema externo ayuda a la máquina a

establecer cuando toma una buena o mala decisión con base en recompensas que se van dando durante el periodo de entrenamiento.

Hoy en día la información se ha convertido en el nuevo oro que hay que explotar en el momento indicado, que puede ser la solución para encontrar nuevas tendencias, incluso puede ser el punto de partida para nuevas oportunidades de negocio. En este orden de ideas, uno de los problemas más comunes a los cuales se pueden enfrentar las organizaciones sin importar su tamaño es recolectar y procesar grandes volúmenes de datos que están generando. La información viene de todo tipo de fuentes en la internet y es en este punto donde el uso de técnicas de aprendizaje automático (Machine Learning, ML) y aprendizaje profundo (Deep Learning, DL) han revolucionado el análisis de datos en el comercio electrónico (Zhang et al., 2023). Estas metodologías permiten el desarrollo de modelos avanzados capaces de clasificar y predecir el sentimiento de los consumidores, para así dar un manejo estable a estos grandes volúmenes de datos.

Investigaciones previas han demostrado que la combinación de técnicas de Machine Learning, NLP y Web Scrapping no solo facilitan el procesamiento y extracción de información relevante a partir de reseñas de los consumidores, sino que también se han convertido en una alternativa sostenible para el análisis de sentimiento; tal es el caso de la investigación *Aplicación de la minería de datos en el marketing usando el análisis de sentimientos de los clientes e-commerce* de Petrlik Azabache et al. (2024), que demostró que estas metodologías tienen la capacidad de exponer cuál es la percepción de los clientes y también ser un complemento estratégico para el marketing dentro de las organizaciones pues, por ejemplo, se pueden extraer de una manera más fácil y rápida los patrones y resultados de campañas publicitarias recién lanzadas.

Igualmente, en el artículo *Stage by stage E-Commerce market database analysis by using machine learning models* de Ryali et al. (2024), los autores concluyen que la combinación

de un entendimiento profundo en marketing y el uso estratégico de modelos de aprendizaje automático pueden ayudar a los vendedores en línea a predecir comportamientos de los consumidores optimizando así el uso de estrategias de marketing e incrementando el retorno en la inversión (ROI).

Adicionalmente, esta combinación de técnicas contribuye a la optimización de la experiencia del cliente en plataformas de comercio electrónico. Estos modelos permiten a los vendedores identificar áreas de mejora, realizar análisis de mercado y competencia, y tomar decisiones basadas en datos para fortalecer su posicionamiento dentro de plataformas como Mercado Libre (Espitaleta et al., 2022).

Marco institucional

Mercado Libre¹ es una de las compañías tecnológicas más relevantes de América Latina, reconocida por haber transformado el comercio electrónico y los servicios financieros digitales en la región. Fundada en 1999 en Argentina, la empresa nació con una misión clara: democratizar el acceso al comercio y al dinero mediante el uso de la tecnología. Desde entonces, ha evolucionado hasta convertirse en un ecosistema digital integral, presente en 18 países y conformado por diversas unidades de negocio que incluyen su plataforma de marketplace, pagos digitales, soluciones logísticas, financiamiento y publicidad.

A través de herramientas como Mercado Pago, Mercado Envíos, Mercado Crédito y Mercado Ads, Mercado Libre no solo conecta a millones de usuarios, sino que también impulsa el crecimiento de emprendedores, pequeñas empresas y grandes marcas en entornos digitales. Su constante innovación, junto con un enfoque en la inclusión financiera, la sostenibilidad y el

¹ Basado en <https://news.mercadolibre.com/historia-de-mercado-libre>

desarrollo económico regional, la posiciona como un actor clave en el panorama empresarial de América Latina.

Mercado Libre se enmarca principalmente en el sector terciario de la economía, también conocido como el sector de servicios, ya que su actividad se centra en la prestación de servicios digitales vinculados al comercio, las finanzas y la tecnología. Sin embargo, su modelo de negocio también abarca funciones logísticas y financieras, lo que le otorga un carácter transversal dentro de este sector. Dentro del sector terciario, Mercado Libre opera específicamente en las siguientes industrias:

- Tecnologías de la información y la comunicación (TIC): Como plataforma tecnológica, desarrolla e implementa soluciones digitales para facilitar transacciones electrónicas, análisis de datos, automatización de procesos y seguridad informática.
- Comercio electrónico (e-commerce): Es su actividad principal, a través de su marketplace, donde usuarios y empresas compran y venden bienes de forma digital. Esto lo posiciona como líder regional en el comercio minorista en línea.
- Servicios financieros digitales (fintech): Con su unidad Mercado Pago, la compañía ofrece servicios de pago, transferencias, cobros electrónicos, billetera digital y acceso al crédito, contribuyendo a la inclusión financiera en América Latina.
- Logística y distribución: A través de Mercado Envíos, la empresa gestiona operaciones logísticas como almacenamiento, empaquetado, despacho y entrega de productos, complementando el circuito de comercio electrónico.
- Publicidad digital: Con Mercado Ads, participa en la industria del marketing y la publicidad en línea, brindando espacios y herramientas para que los vendedores promocionen sus productos en la misma plataforma.

En conjunto, estas actividades sitúan a Mercado Libre como un actor estratégico en la economía digital latinoamericana, con fuerte impacto en el desarrollo del comercio, la innovación tecnológica y la transformación de los servicios tradicionales.

Enfoque, alcance y diseño de la investigación

Este estudio aborda un enfoque de carácter cuantitativo, que busca aplicar técnicas de Procesamiento de Lenguaje Natural (NLP), Machine Learning y análisis estadístico para describir las tendencias dentro de las opiniones de los usuarios, sus preocupaciones y principales características. De esta manera, se busca predecir el sentimiento de los usuarios de productos de calzado de descanso en MercadoLibre Colombia.

Es común que los proyectos de minería de datos y analítica se centren en sus primeras fases en las descripciones y hallazgos del conjunto de datos (Petrlik Azabache et al., 2024), por este motivo se determina que el alcance es descriptivo, ya que este “tiene como finalidad especificar propiedades y características de conceptos, fenómenos, variables o hechos en un contexto determinado” (Hernández Sampieri, et al. 2021, p.145) y con este estudio se espera identificar patrones específicos derivados de las reseñas de los clientes que nos permita identificar las emociones y la percepción en el proceso de comprar.

El diseño elegido para la investigación es no experimental y transversal, teniendo en cuenta que dentro del estudio no hay manipulación del entorno y sus variables, sino la observación directa para construir un análisis tal como se presenta en la plataforma para analizar y sacar así información relevante que pueda ser utilizada para la toma de decisiones.

Definición de variables

A continuación, se presentan las variables que serán consideradas en esta investigación, divididas en principales y contextuales, con sus respectivas definiciones conceptuales, operacionales y su clasificación según dimensión y escala de medición.

Tabla 1 Variables Principales

Variable	Definición conceptual	Definición operacional	Dimensión - Escala
Review (Texto de la reseña)	Opinión escrita por el usuario en la sección de comentarios de la publicación, donde manifiesta su experiencia con el producto.	Se extrae por medio de Web Scraping desde la plataforma Mercado Libre. Posteriormente, se preprocesa para ser utilizado como entrada del modelo usando la metodología descrita en la siguiente sección.	Cualitativa – Cuantitativa después de procesamiento
Calificación (estrellas)	Representa la valoración numérica del producto otorgada por el usuario en una escala de satisfacción (1 a 5 estrellas).	Se extrae de la misma reseña, como valor numérico ordinal. Puede ser comparada con el sentimiento textual para verificar consistencia.	Cuantitativa ordinal
Sentimiento	Se refiere a la carga emocional (positiva, negativa o neutra) expresada por el usuario en su reseña sobre el producto. Representa su percepción subjetiva y evaluación emocional.	Se determina mediante un modelo de Machine Learning entrenado con técnicas de Procesamiento de Lenguaje Natural (NLP), que clasifica automáticamente los textos en categorías de sentimiento.	Categoría nominal
Viabilidad del modelo (desempeño técnico del modelo de ML)	Se refiere a la capacidad técnica y práctica del modelo de Machine Learning para clasificar correctamente los sentimientos en los textos analizados, en términos de eficiencia y precisión.	Se evalúa mediante métricas de desempeño como Accuracy, Precision, Recall, F1-score y ROC AUC, calculadas sobre un conjunto de datos de validación.	Cuantitativa

Fuente: Elaboración propia

Tabla 2 Variables de Contexto

Variable	Definición conceptual	Definición operacional	Dimensión - Escala
Precio	Monto en dinero que cuesta el producto, expresado en pesos colombianos, visible en la publicación.	Se obtiene directamente desde la plataforma mediante Web Scraping como valor numérico.	Económica - Cuantitativa continua
Vendidos	Número de unidades del producto vendidas hasta la fecha de recolección, como indicador de demanda.	Se toma del contador público visible en la página del producto.	Comercial - Cuantitativa discreta
Calificación del vendedor	Calificación general del vendedor en la plataforma, basada en su desempeño anterior y las evaluaciones recibidas.	Se toma del perfil del vendedor. Puede aparecer como porcentaje o como nivel (ej. "MercadoLíder Gold").	Reputacional - categórica
Cantidad de calificaciones	Número total de calificaciones o reseñas recibidas por el producto hasta el momento de la recolección.	Se extrae como valor numérico visible en la parte superior de la publicación.	Cuantitativa discreta
Detalle (nombre del producto)	Denominación comercial o título del producto en la plataforma, utilizado como descriptor para agrupar reseñas.	Se obtiene como texto desde el encabezado de la publicación en Mercado Libre.	Descriptiva - Cualitativa.

Fuente: Elaboración propia

Estas variables son utilizadas para estructurar la base de datos del estudio, alimentar el modelo de análisis de sentimiento y evaluar el rendimiento del algoritmo aplicado, en el marco de la categoría de calzado de descanso en Mercado Libre Colombia. La inclusión de variables contextuales permite enriquecer el análisis descriptivo y brindar información complementaria relevante para la toma de decisiones estratégicas.

Población y Muestra

Los datos base para esta investigación son recolectados mediante Web Scraping a partir de los productos de calzado de descanso más vendidos en Mercado Libre Colombia que, además, cuentan con reseñas, preguntas o comentarios disponibles; lo cual quiere decir que la muestra utilizada es de carácter no probabilístico y dirigida. Esta selección no obedece a un criterio de aleatoriedad, sino que responde a un enfoque intencional, centrado en analizar aquellos productos con mayor volumen de interacción de los usuarios.

Las muestras no probabilísticas son apropiadas cuando se requiere seleccionar elementos con características específicas o representativas para los fines del estudio, especialmente en etapas exploratorias o cuando se analizan fenómenos en contextos particulares (Hernández Sampieri et al., 2021). En este caso, al centrarse en productos con reseñas, la muestra se ve influenciada por el comportamiento voluntario de los usuarios que decidieron compartir su experiencia, lo que puede introducir sesgos como una sobre-representación de opiniones extremas. No obstante, la riqueza, profundidad y calidad de la información permitiría identificar patrones significativos en las percepciones del consumidor y generar recomendaciones estratégicas fundamentadas.

Este tipo de muestreo implica que los resultados no son generalizables al total de productos ni a la totalidad de compradores, sino que se enfocan en artículos con mayor visibilidad dentro de la plataforma, que tienden a recibir más retroalimentación. La elección de este subconjunto se justifica considerando el objetivo general del estudio, que pretende evaluar la viabilidad de un modelo de análisis de sentimiento a partir de datos reales y relevantes para la toma de decisiones comerciales.

Metodología de la investigación

Se describe el proceso para evaluar la viabilidad de un modelo de Machine Learning aplicado al análisis de sentimientos en la categoría de calzado de descanso de Mercado Libre Colombia. Se adopta la metodología CRISP-DM ampliamente utilizada en proyectos de ciencia de datos por su estructura sistemática y adaptable. Esta metodología consta de varias etapas, que abarcan desde la comprensión del negocio y los datos hasta el análisis de los resultados del modelo².

1. Comprensión del negocio: Se identifican los objetivos principales del proyecto, que incluyen caracterizar la percepción de los consumidores frente a los productos de calzado de descanso, y explorar cómo se manifiestan sentimientos positivos, negativos o neutros en sus opiniones.

2. Comprensión de los Datos

2.1 Diseño de script: Se elabora un script programático y así se automatiza el proceso de extracción de datos mediante la librería BeautifulSoup, todo mediante Python para el web scraping y el análisis de datos. Se utiliza una estructura que conlleva tareas puntuales, que se conecte a la página web, navegue y registre las actividades (reviews).

2.2 Extracción de información: Se extraen las reseñas y comentarios relacionados con la categoría de calzado de descanso y su puntuación desde la página web de mercado libre, obteniendo una muestra de los productos con mayor número de comentarios. Estos datos extraídos serán guardados en formatos CSV para futuros procesamientos y adicionalmente existirá un mecanismo de validación para tener confianza en la

² Basado en la metodología CRISP-DM (Cross-Industry Standard Process for Data Mining).
<https://www.ibm.com/docs/es/spss-modeler/saas?topic=dm-crisp-help-overview>

información obtenida. Se tiene en cuenta el cumplimiento de las políticas de la página web para evitar problemas de acceso.

3. Preparación de los datos

3.1 Limpieza y procesamiento: Luego de la extracción, los datos pasan a la etapa de limpieza y procesamiento donde se eliminan datos duplicados o datos que no aporten al análisis, se pasan los textos a minúsculas, se eliminan las puntuaciones, números o cualquier otro carácter no importante. Según Shashank Mohan Jain (2022), este proceso está fundamentado en diferentes técnicas dentro de las cuales destacan:

- **Tokenización:** Consiste en dividir el texto extraído en palabras o frases más pequeñas para su posterior análisis.
- **Lematización y Stemming:** Es el proceso de reducir las palabras a su forma base para evitar variaciones innecesarias durante el análisis.
- **Eliminación de stopwords:** Es el proceso esencial de remoción de palabras vacías o que no aportan un valor semántico y generan sobre dimensionalidad y ruido durante el análisis, es decir, eliminar palabras como “él”, “la”, “y”, “los”, etc.
- **Vectorización:** Significa tomar los tokens obtenidos y aplicarlos a un espacio vectorial donde dejan de ser palabras o cadenas de texto para convertirse en valores numéricos que los algoritmos de Machine Learning puedan procesar.

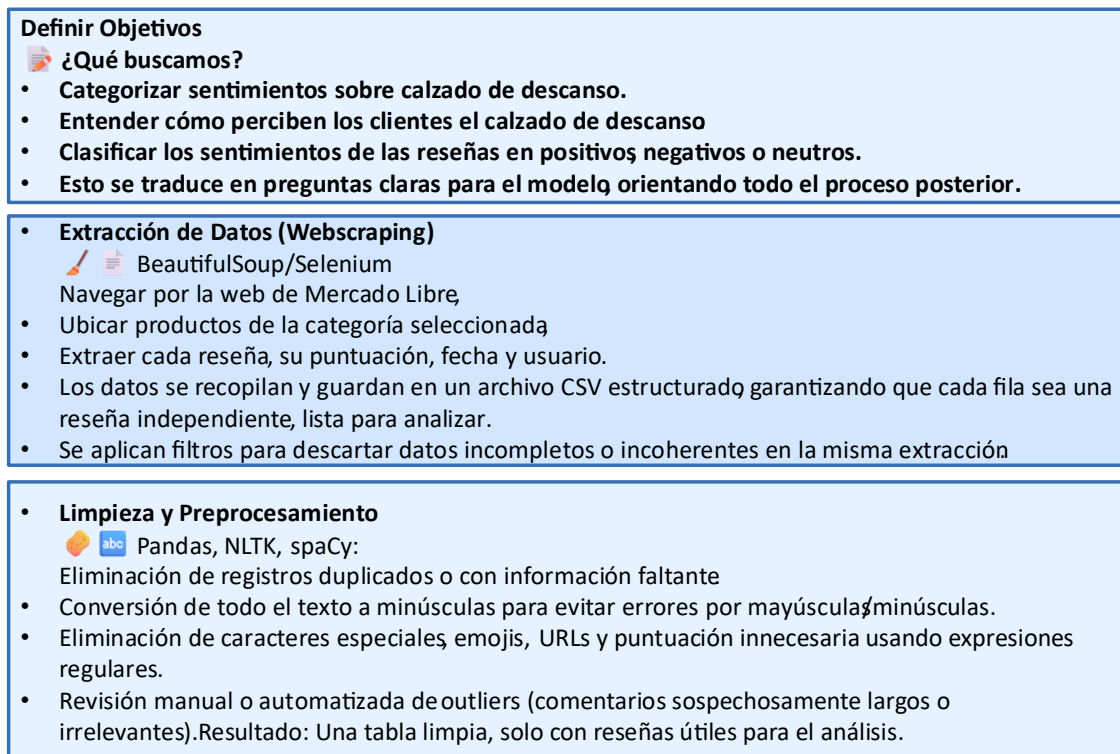
3.2 Análisis exploratorio de datos (EDA): Se enfoca en la distribución de datos preprocesados. Por medio de un análisis descriptivo utilizaremos datos estadísticos tales como la media, la mediana y desviaciones para obtener información de las características de los reviews. Adicionalmente, se analizan correlaciones para obtener patrones.

4. **Modelado:** Ya con toda la información procesada empieza la etapa de la modelación y su respectivo aprendizaje supervisado mediante el modelo de NLP. Se divide la muestra en conjuntos de entrenamiento y prueba.
5. **Evaluación:** Se utilizan las métricas de evaluación *Accuracy*, *precisión* y *recall*, *F1-score*, *Curva ROC* y *AUC* y la matriz de confusión, con el fin de analizar la validez de los resultados.
6. **Despliegue y resultados:** Los resultados obtenidos se presentan mediante estadísticas y resultados con la distribución de sentimientos de las reseñas y las tendencias. Sirve para demostrar la viabilidad del modelo de Machine Learning y sus predicciones.

Figura 1



Flujo del proyecto de ML para análisis de sentimientos

Flujo de Procesamiento de Datos para Análisis de Sentimientos



Flujo de Procesamiento de Datos para Análisis de Sentimientos



- **Tokenización y Vectorización**

  NLTK, scikit-learn: A cada reseña.

Tokenización : Dividir los textos en palabras individuales (tokens), separando las frases en “bloques” comprensibles por la máquina.

- **Eliminación de stopwords**: Quitar palabras vacías que no aportan valor semántico (“el”, “la”, “y”, “pero”, etc.).
- **Lematización o stemming**: Reducir las palabras a su raíz (“comprando” → “comprar”). Este proceso reduce el “ruido” del texto y deja solo la información relevante para el modelo.

- **Análisis Exploratorio de Datos (EDA)**

  Pandas, Matplotlib: Gráficar.

Ver la distribución de sentimientos en las reseñas.

- Analizar la frecuencia de palabras (palabras más comunes, nube de palabras).
- Detectar patrones o correlaciones entre variables (por ejemplo, relación entre calificación y sentimientos).
- Esto ayuda a entender los datos antes de entrenar el modelo y a tomar decisiones sobre posibles ajustes.

Flujo de Procesamiento de Datos para Análisis de Sentimientos

• **Modelado y Entrenamiento**



scikit-learn, TensorFlow (Datos de pruebas y de entrenamiento).

- Se selecciona un modelo de clasificación (por ejemplo, regresión logística, SVM, MLP, etc.).
- Se entrena el modelo usando las reseñas etiquetadas permitiendo que aprenda a reconocer patrones asociados a sentimientos positivos, negativos y neutros.
- Se ajustan los hiperparámetros para mejorar la precisión.
- El modelo aprende a “predecir” el sentimiento de nuevas reseñas.

• **Evaluación**



scikit-learn

- Se calculan métricas como accuracy, precision, recall, F1-score, matriz de confusión, curva ROC y AUC.
- Se interpretan los resultados para saber si el modelo es fiable y en qué casos se equivoca más.
- Si es necesario, se realizan iteraciones para mejorar el rendimiento del modelo.

• **Presentación de Resultados**



Matplotlib

- Gráficas de Python sobre la distribución de sentimientos, tendencias a lo largo del tiempo, y productos con mejores/peores reseñas.
- Tablas resumen y recomendaciones para la toma de decisiones.
- Análisis visual que ayude a entender el impacto de las opiniones de los usuarios en la categoría analizada.

Fuente: Elaboración propia

Selección de métodos para recolección de información

La comprensión del negocio de la categoría de calzado de descanso en Mercado Libre inició con la extracción de la información que permitiera el análisis de variables como precio, calificación del vendedor y los productos, número de unidades vendidas, entre otras. Esta extracción se realizó mediante el entendimiento del código HTML de la página web de Mercado Libre, el cual es muy dinámico y requirió de diferentes pruebas hasta que se logró diseñar un script que permitiera, luego de varias iteraciones, obtener la información deseada.

El diseño del script requirió la utilización de librerías como BeautifulSoup y Re y todo el diseño de la extracción de información se desarrolló en lenguaje Python a través de cuadernos de Jupyter Notebooks para su fácil iteración y validación.

El script recorrió las publicaciones pertenecientes a la categoría y activas en ese momento, logrando la extracción de un total de 2.726 productos con las respectivas variables de contexto (precio, unidades vendidas, reputación del vendedor, etc.) de igual manera un total de 4.716 comentarios asociados a estas publicaciones, junto con la calificación otorgada en estrellas y la fecha de publicación (esta última variable que no será tomada en cuenta dentro del estudio al ser de carácter transversal).

Técnicas de análisis de datos

Una vez consolidada la información extraída, se aplicó preprocesamiento y limpieza a los datos, buscando la mejor estructura según lo requerido, para así analizar las variables planteadas en el diseño metodológico. Este preprocesamiento se realizó en dos capas, la primera depuración se realizó en Python donde se buscó dar estructura y sentido a los datos para su fácil entendimiento. En esta parte se eliminaron duplicados y registros vacíos que no aportaban valor, de igual manera se realizó una transformación de los valores de las columnas para que respondieran a su naturaleza numérica o categórica según cada caso. Se aplicó una primera normalización a las variables como vendedor y reputación para así poder consolidar dos bases de datos en Excel donde se presentan las variables según su naturaleza, es decir hay una base de datos que consolida la información de las variables contextuales para el total de los productos y otra base de datos que consolida la totalidad de los comentarios que son el insumo principal para los modelos de Machine Learning que van a ser entrenados.

Posterior a esto, la base de datos de los comentarios se procesó con la finalidad de estandarizar el material extraído y que así las técnicas de NLP dieran información relevante

dentro del estudio. Dentro del procesamiento de los comentarios se realizó una normalización a minúsculas y eliminación de tildes para reducir la cantidad de palabras dentro del corpus, se eliminó ruido de la información quitando la totalidad de urls encontradas, emojis, signos de puntuación y caracteres especiales que no aportarían relevancia al análisis.

Se desarrolló una función de limpieza de manera iterativa con las librerías NLTK y spaCY que permitiera aplicar al corpus de texto, eliminación de stopwords, lematización, stemming y tokenización de manera controlada y donde se pudiera observar el impacto que tenía en los comentarios.

Finalmente, se entrenaron modelos supervisados de Machine Learning, específicamente algoritmos como Redes Neuronales y BERT. Cada modelo se evaluó según su rendimiento mediante métricas de desempeño como Accuracy, Precision, Recall, F1-score y ROC AUC. Este enfoque asegura un análisis completo, claro y técnicamente robusto para generar resultados confiables y que puedan ser útiles para determinar su posible implementación. En el Anexo 1 se describen las herramientas, librerías y algoritmos utilizados.

Análisis y discusión de los resultados


Resultados descriptivos

Como se mencionó anteriormente, se recopilaron datos de 2.726 productos registrados en la categoría de calzado de descanso. De ellos, el 32% correspondía a artículos nuevos, los cuales aún no contaban con registros de ventas, comentarios ni calificaciones.

Al analizar el contenido de las descripciones de los productos, se observa que las palabras más comunes están relacionadas con términos como pantuflas, sandalias y mujer, destacándose especialmente la mención de la característica antideslizante. El análisis de bigramas (combinaciones frecuentes de dos palabras) revela que las expresiones más repetidas son babuchas pantuflas y chancas sandalias, lo cual confirma que estos son los tipos de

Figura 3

Histograma cantidades vendidas por producto




Fuente: Elaboración propia

Un patrón similar se observa en los comentarios, con un promedio de 9 por producto, pero una mediana de apenas 1. Algunos productos llegaron a acumular hasta 996 comentarios. Como se muestra en el gráfico de dispersión, aquellos productos con mayores ventas tienden a recibir más calificaciones.

Figura 4

Gráfico de dispersión entre la cantidad vendida y el número de calificaciones por producto

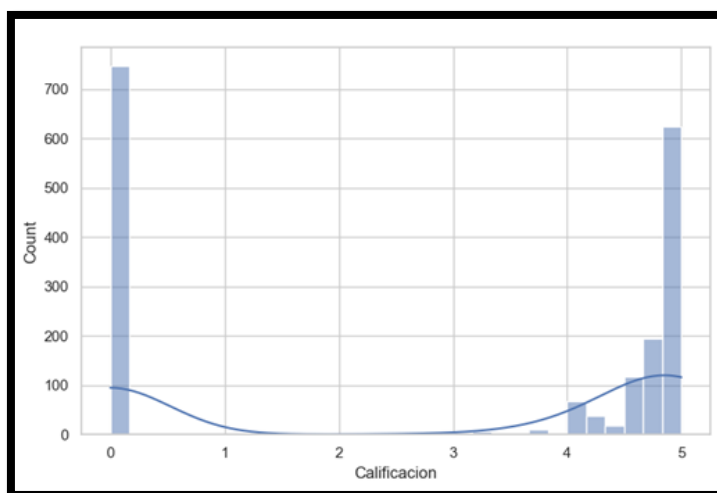


Fuente: Elaboración propia

Al analizar la distribución de las calificaciones, se observa que la mayoría de los productos están bien evaluados, con puntuaciones entre 4 y 5 estrellas. No obstante, también se identifica un número considerable de productos que aún no han recibido ninguna calificación. Esto sugiere una distribución sesgada hacia las valoraciones positivas, como se muestra en el siguiente gráfico.

Figura 5

Histograma de calificaciones de los productos



Fuente: Elaboración propia

En cuanto a los comentarios, estos son menos frecuentes que las calificaciones: el promedio es de 3 por producto, pero más del 50% no tiene ninguno. El producto con mayor número de comentarios acumuló un total de 355. Entre los comentarios disponibles, predominan las valoraciones positivas, donde se destacan adjetivos como *excelente*, *buen producto*, *buena calidad* y *cómodo*, lo que sugiere una percepción principalmente favorable por parte de los compradores, lo que va en línea con que las calificaciones más comunes sean las altas y se encuentren entre 4 y 5. Esta tendencia es coherente con la distribución de calificaciones, donde las más comunes son las altas: el 79% de los comentarios están asociados a la calificación

máxima (5 estrellas), el 12% a calificaciones de 4 estrellas, el 4% a 3 estrellas, y solo el 4% corresponde a puntuaciones negativas (1 y 2 estrellas).

Figura 6

Nube de palabras de los comentarios



Fuente: Elaboración propia

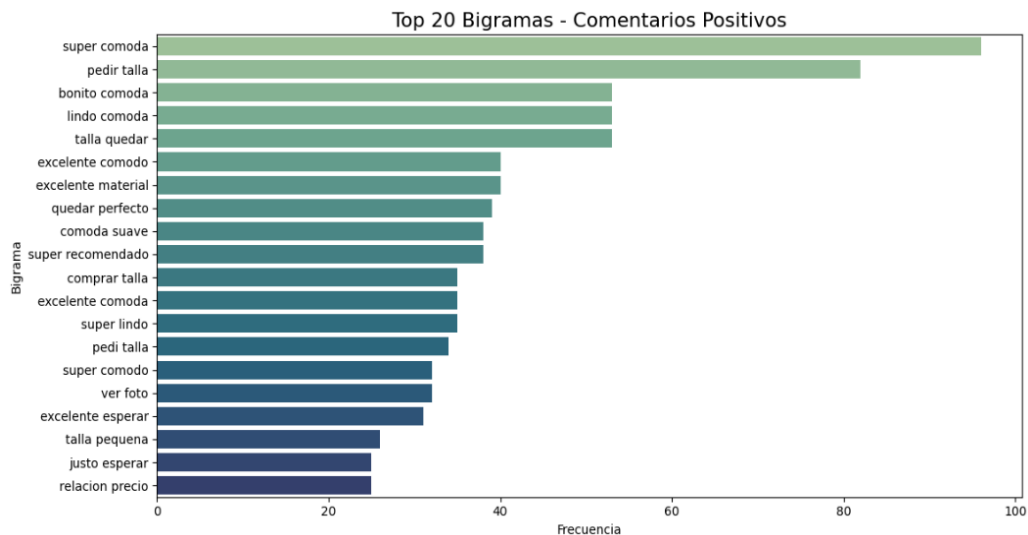
En promedio, los comentarios tienen una longitud de 10 palabras. Sin embargo, los comentarios tienden a ser más extensos en los productos con calificaciones más bajas. Por ejemplo, los comentarios asociados a productos con 5 estrellas tienen una media de 9 palabras, mientras que aquellos con 4 estrellas alcanzan las 13 palabras. Esta longitud aumenta a 15 y 16 palabras en los comentarios con calificaciones de 2 y 1 estrella, respectivamente, y llega a un promedio de 18 palabras en los comentarios con 3 estrellas. Este patrón sugiere que los clientes más satisfechos suelen dejar opiniones breves, mientras que los menos satisfechos tienden a detallar más su experiencia para explicar su inconformidad.

Al analizar las palabras más frecuentes en los comentarios según la calificación otorgada, se evidencian diferencias significativas, especialmente entre las valoraciones de 4 y 5 estrellas frente al resto. Los comentarios asociados a calificaciones altas tienden a resaltar aspectos positivos mediante adjetivos como bonito, lindo, excelente y perfecto, así como atributos

relacionados con la comodidad (cómodo, suave). Además, hacen referencia favorable a características como la talla, los materiales y la relación precio-calidad.

Figura 7

Frecuencia de principales bigramas de los comentarios de productos calificados con 4 y 5 estrellas




Fuente: Elaboración propia

En contraste, los comentarios de productos calificados con 3 estrellas presentan un tono más negativo, mencionando aspectos como que el producto queda pequeño, los materiales son duros o la suela se desgasta rápidamente. Este patrón se intensifica en las valoraciones de 2 y 1 estrella, donde predominan menciones a problemas como tallas incorrectas, publicidad engañosa, mala calidad y falta de suavidad. Teniendo en cuenta lo anterior, se observa que los comentarios asociados a la calificación de 3 estrellas, que en principio representa una opinión neutral, tienden a alinearse más con percepciones negativas. Esto sugiere que, en la práctica, los usuarios utilizan esta calificación para expresar cierto grado de insatisfacción, aunque podría no ser tan marcado como en las valoraciones de 1 o 2 estrellas.

Figura 8


Frecuencia de principales bigramas de los comentarios de productos calificados con 3 estrellas



Fuente: Elaboración propia

Figura 9

Frecuencia de principales bigramas de los comentarios de productos calificados con 2 y 1 estrellas




Fuente: Elaboración propia

Respecto al precio, los productos de calzado de descanso que se encuentran en Mercado Libre oscilan entre \$9.900 y \$600.000 pesos, lo que refleja una gran variabilidad. Al analizar la relación entre ventas y precio, se observa que los productos más vendidos no superan los

\$150.000, mientras que aquellos con bajas ventas presentan un rango de precios más amplio, que puede llegar hasta cerca de \$600.000 pesos.

Figura 10

Gráfico dispersión entre la cantidad vendida y el precio de los productos



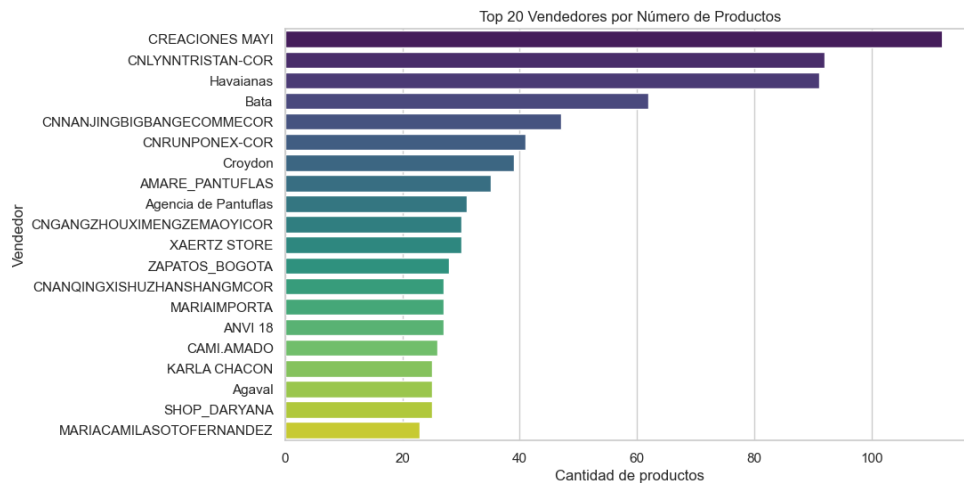
Fuente: Elaboración propia

Al analizar las tendencias del mercado en la categoría de calzado de descanso en Mercado Libre Colombia, se evidencia que la cantidad de productos publicados por un vendedor no necesariamente se traduce en un mayor volumen de ventas. Es decir, hay vendedores con amplios catálogos que tienen pocas unidades vendidas, mientras que otros, con menos publicaciones, figuran entre los que más comercializan. Además, se identificó que entre los vendedores con mayores ventas existe una variabilidad considerable en la calificación de su reputación: algunos cuentan con distinciones destacadas como Mercado Líder *Gold* o *Platinum*, que la plataforma otorga a quienes mantienen buenos niveles de cumplimiento, atención y satisfacción; sin embargo,

también hay casos de vendedores con reputaciones intermedias o incluso sin reconocimiento alguno que igualmente logran altos volúmenes de ventas. Esto sugiere que la calificación del vendedor no siempre es el factor más determinante para el comprador, al menos en esta categoría. Por otro lado, una gran proporción de vendedores aún no posee una reputación visible en la plataforma, lo cual podría deberse a que no han alcanzado el umbral mínimo de transacciones necesarias para ser evaluados. Según las políticas de Mercado Libre, estas insignias implican un desempeño consistente en tiempos de entrega, volumen de ventas, atención al cliente y baja tasa de reclamos, lo que deja ver que la ausencia de reputación no implica necesariamente una mala experiencia, sino que puede estar asociada a nuevos vendedores o baja actividad reciente.

Figura 10

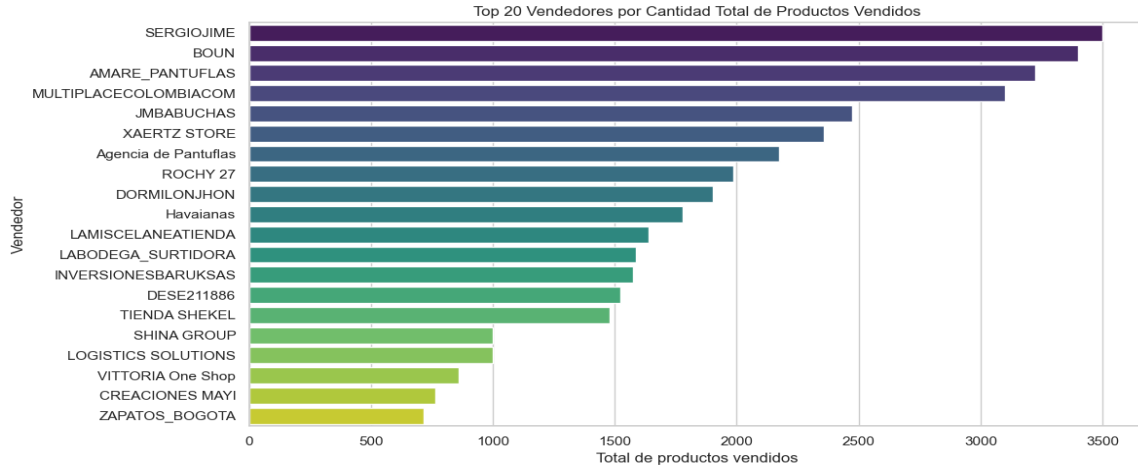
Top de vendedores por número de productos



Fuente: Elaboración propia

Figura 11

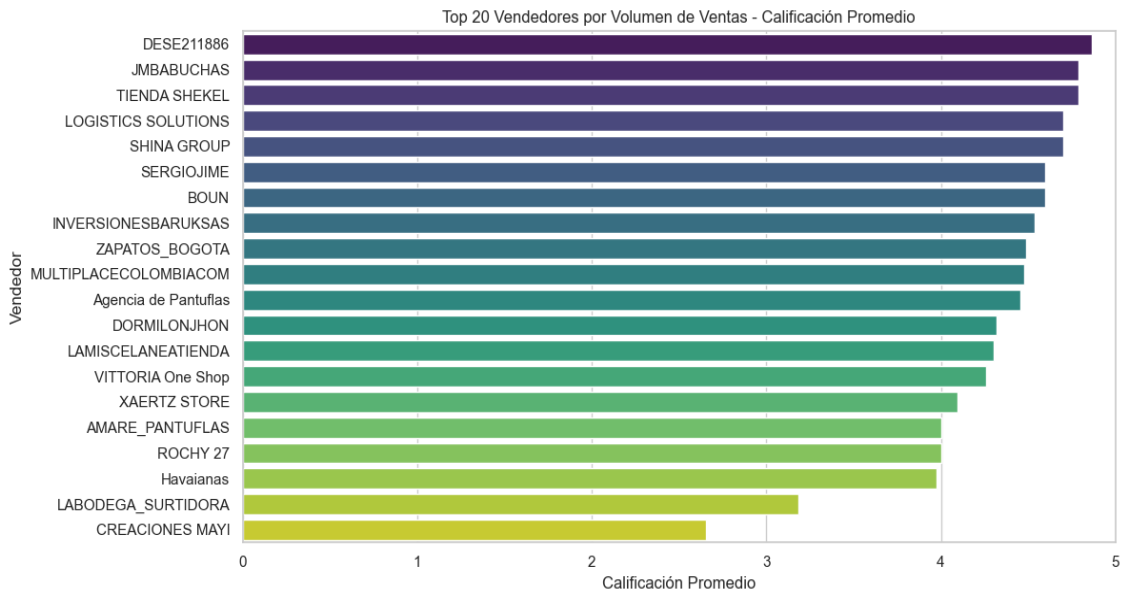
Top de vendedores por cantidad de productos vendidos



Fuente: Elaboración propia

Figura 12

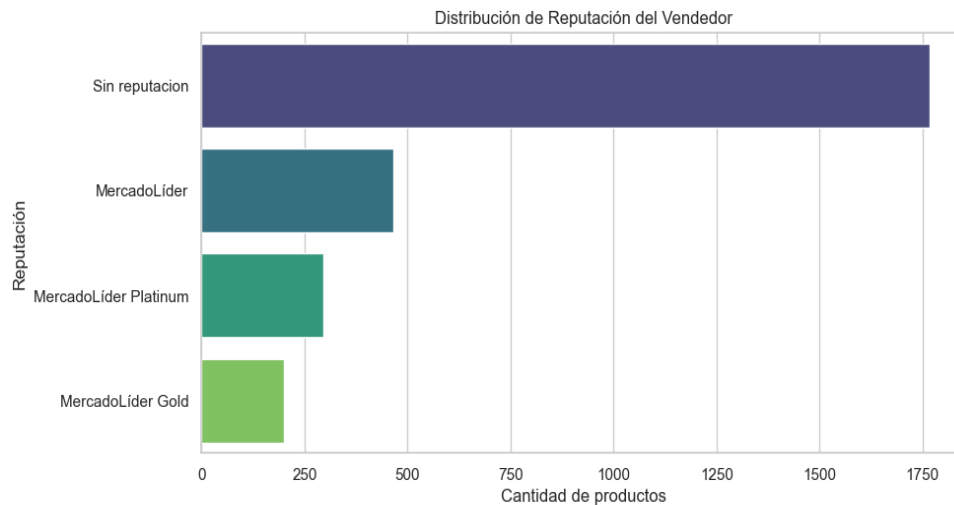
Top de vendedores por volumen de ventas



Fuente: Elaboración propia

Figura 13

Reputación del vendedor



Fuente: Elaboración propia

Resultados del modelo

El entrenamiento de modelos de Machine Learning tiende a ser un proceso iterativo, los modelos tienen un gran número de parámetros que se pueden ajustar en cada iteración para encontrar los mejores resultados, que el conjunto de datos extraído y procesado permita obtener. El proceso de escoger el modelo más adecuado depende de la obtención de las mejores métricas posibles, con las que se puede entonces determinar el o los modelos más robustos que pueden ser utilizados en producción de aplicativos relacionados con la interpretación del sentimiento de los consumidores. La tabla presentada a continuación detalla el resumen de los principales modelos de entrenamiento desarrollados:

Tabla 3 Modelos Entrenados

Modelo	Hiperparámetros clave	Accuracy	Precisión Positivo	Precisión Negativo	Precisión Neutro	Recall Positivo	Recall Negativo	Recall Neutro	F1 Positivo	F1 Negativo	F1 Neutro
CNN Ensemble (Binario, Undersampling, Neutro = Negativo)	100 modelos bagging, undersampling 1:1	0.85	1.00	0.36		0.84	1.00		0.91	0.53	
CNN Ensemble (Binario, Undersampling)	100 modelos bagging, undersampling 1:1	0.80	1.00	0.17		0.79	1.00		0.88	0.29	
LSTM Ensemble (Binario, Undersampling)	10 modelos, undersampling 1:1	0.85	0.98	0.38		0.82	0.85		0.91	0.52	
LSTM (BiLSTM) Ensemble	30 modelos bagging, undersampling 1:1	0.79	0.99	0.28		0.78	0.89		0.87	0.43	
BERT - BETO (Esp), Binario	3 epochs, class_weights	0.91	0.99	0.51		0.92	0.88		0.95	0.65	
CNN (Binario, Neutro = Negativo)	conv1D, kernel 8, 64 filtros, 50 epochs, class_weights, early_stop	0.90	0.95	0.44		0.94	0.49		0.94	0.46	
CNN (Multiclase)	conv1D, kernel 5, 128 filtros, 50 epochs, class_weights, early_stop	0.86	0.96	0.27	0.22	0.90	0.39	0.38	0.93	0.32	0.28
BERT - BETO (Esp), Binario	3 epochs, optimizer Adam, loss CategoricalCrossentropy	0.90	0.94	0.45		0.96	0.36		0.95	0.40	
MLP (10 épocas)	3 capas, 128 neuronas, lr=0.001, relu, Adam	0.96	0.97	0.64		0.99	0.35		0.98	0.35	
CNN (Multiclase, Oversampling)	conv1D, kernel 5, 64 filtros, 50 epochs, class_weights, early_stop	0.89	0.94	0.34	0.24	0.95	0.29	0.26	0.94	0.31	0.25
BERT - BETO (Esp), Multiclase	3 epochs, optimizer Adam, loss CategoricalCrossentropy	0.91	0.93	0.48	0.16	0.98	0.29	0.07	0.95	0.36	0.10
MLP (4 épocas, Early Stop)	3 capas, 128 neuronas, lr=0.001, relu	0.96	0.97	0.59		0.99	0.26		0.98	0.36	

Fuente: Elaboración propia

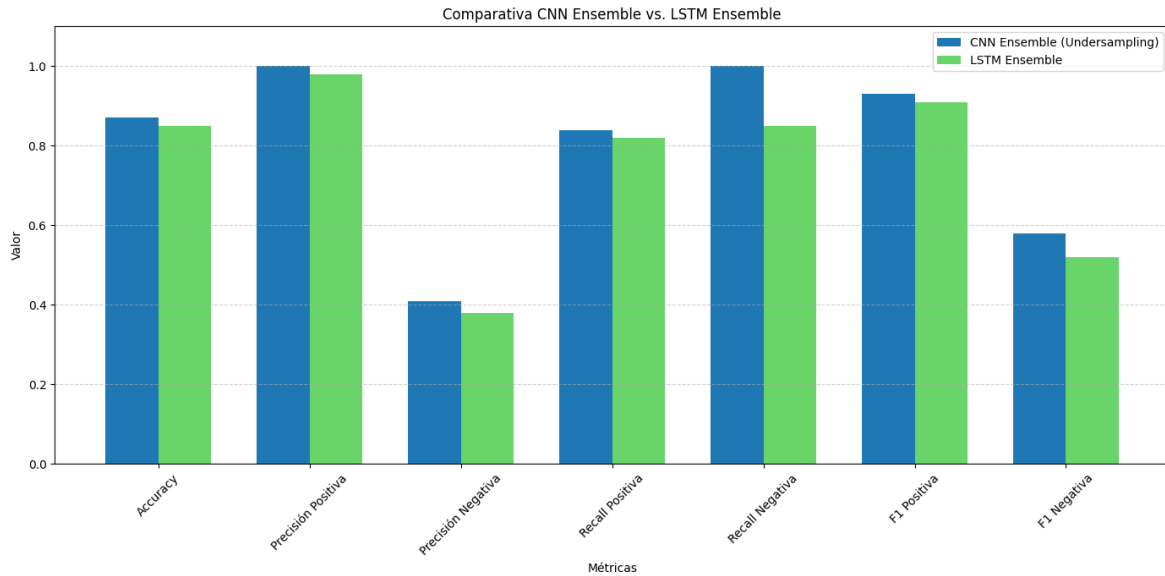
Dado que en esta investigación los sentimientos negativos tienen un mayor peso, al representar quejas, inconformidades o reclamos, resultó fundamental maximizar la detección de comentarios negativos. En este contexto, el recall de la clase negativa (Recall Negativo) se convierte en una métrica clave, ya que indica cuántos de los comentarios verdaderamente negativos fueron correctamente identificados por el modelo.

Por su parte, la métrica F1 de la clase negativa (F1 Negativo) ofrece una visión equilibrada entre precisión y recall, y resulta especialmente relevante en conjuntos de datos desbalanceados, como el utilizado en este estudio. Esta métrica permite evaluar el desempeño del modelo en la clase minoritaria, ayudando a controlar la aparición de falsos positivos, es decir, aquellos casos en los que un comentario positivo es incorrectamente clasificado como negativo. El accuracy, aunque brinda una visión general del rendimiento del modelo —al indicar el porcentaje total de predicciones correctas—, debe interpretarse con cautela en escenarios de desbalance. En estos casos, un alto accuracy puede ser engañoso, ya que no refleja adecuadamente el desempeño del modelo sobre la clase menos representada, que en este estudio es precisamente la más relevante.

Teniendo en cuenta los criterios mencionados, los dos modelos más representativos con métricas aceptables y mayor viabilidad para el análisis son: CNN Ensemble y LSTM Ensemble. Estos modelos fueron entrenados utilizando únicamente dos categorías: positiva y negativa, considerando que la categoría neutral mostraba una tendencia significativa, hacia comentarios negativos. A pesar de esta reclasificación binaria, el conjunto de datos continuó presentando un desbalance de clases, lo que fue tenido en cuenta durante la evaluación y comparación de los modelos. La figura presentada a continuación muestra una comparativa de las métricas de los dos modelos con mejor desempeño en la clasificación de sentimientos en la categoría de calzado de descanso.

Figura 14

Comparativo de las métricas modelos ML con mayor desempeño



Fuente: Elaboración propia

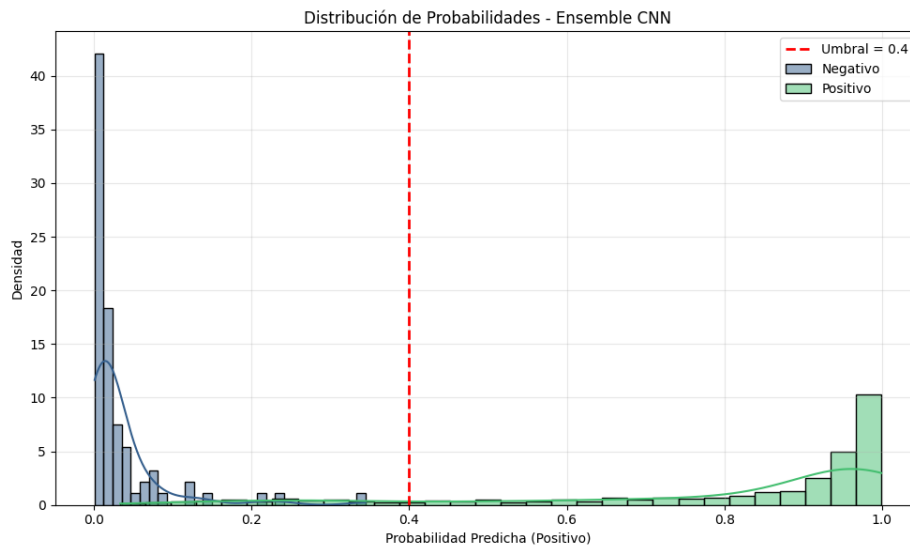
El CNN Ensemble, basado en la estrategia de undersampling y bagging de 100 modelos, logró un Recall del 100% en la clase Negativa, asegurando la detección de la totalidad de comentarios negativos. Sin embargo, esta estrategia agresiva de balanceo conlleva una baja precisión en la clase Negativa (0.41), lo que implica un volumen considerable de falsos positivos. Su F1-score Negativo (0.58) representa un equilibrio moderado, lo que es bueno para su uso en aplicaciones centradas en la detección temprana de quejas o comentarios negativos.

La siguiente gráfica muestra la distribución de probabilidades predichas por el modelo para ambas clases reales (positivo y negativo), junto con la línea punteada vertical que representa el umbral de decisión establecido para el modelo (0.4). Inicialmente este umbral se había establecido en 0.5 de manera conservadora, de esta forma todas las predicciones menores a 0.5 se clasificaban como negativas y las mayores se clasificaban como positivas. El entendimiento de esta gráfica permite mover ese umbral de decisión y en sus resultados pasa

de aproximadamente 141 falsos negativos en 944 datos del conjunto de prueba a 115, lo que representó una mejora del 5% en la precisión de la clase negativa, pasando de (0.36) a (0.41).

Figura 15

Distribución de probabilidades



Fuente: Elaboración propia


La matriz de confusión presenta el comportamiento de clasificación del modelo en el conjunto de prueba que fue optimizado en la métrica Recall de la clase negativa para la detección de comentarios negativos, y así lo demuestran los resultados:

- El modelo no clasificó ningún comentario negativo como positivo (0 falsos positivos)
- Se detectaron 748 verdaderos positivos, lo cual confirma un buen de rendimiento también en la clase mayoritaria.
- El modelo detecto 115 falsos negativos, comentarios positivos que fueron clasificados como negativos. Esto es principalmente consecuencia del uso del undersampling esemble, que favorece el Recall de la clase negativa a costa de sacrificar precisión en la clase positiva.

- El modelo detecto el 100% de los comentarios negativos en el conjunto de prueba.

Figura 16

Matriz de confusión modelo CNN

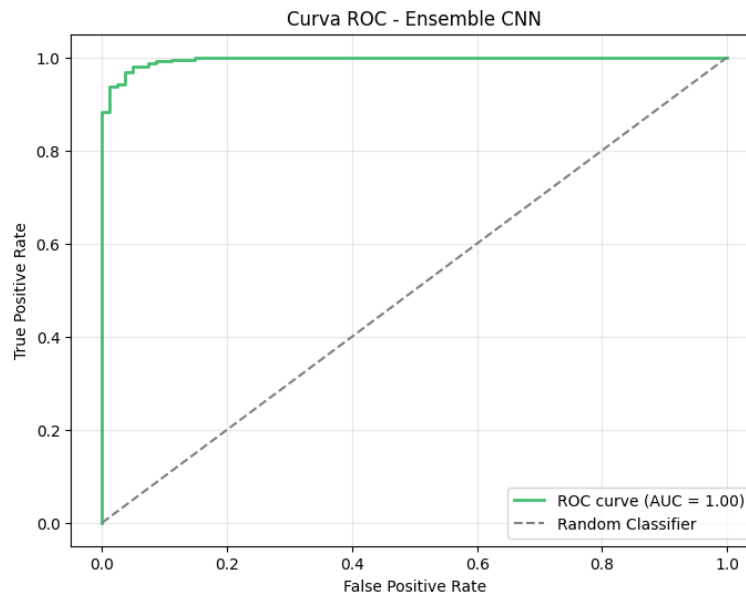


Fuente: Elaboración propia

Métricas complementarias, como la curva ROC presentada a continuación, muestran que el modelo CNN Ensemble tiene una excelente capacidad para diferenciar entre clases, con un AUC de 1.00, lo que indica un desempeño prácticamente perfecto. El modelo logra una alta tasa de verdaderos positivos (Recall) manteniendo una muy baja tasa de falsos positivos, lo que lo hace especialmente confiable para detectar comentarios negativos sin generar clasificaciones erróneas.

Figura 17

Curva ROC – modelo CNN

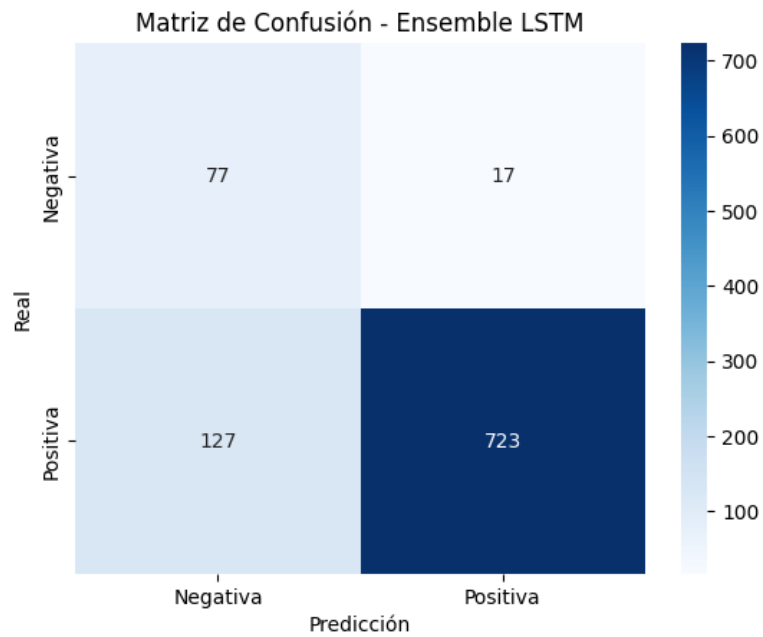


Fuente: Elaboración propia

El LSTM Ensemble, construido mediante una estrategia de undersampling balanceado y bagging de 5 modelos, alcanzó un Accuracy general del 85 % y mostró un alto desempeño en la clasificación de comentarios positivos, con una precisión del 0.98 y un F1-score de 0.91 para esa clase. Sin embargo, debido al desbalance original entre clases, la predicción de comentarios negativos resultó más desafiante, como sucede con el CNN, lo cual se refleja en una precisión negativa de solo 0.38, a pesar de haber logrado un Recall del 0.85 para esa clase. Esto indica que el modelo identificó correctamente la mayoría de los negativos, aunque a costa de incluir muchos falsos positivos. Su F1-score para la clase negativa (0.52) es uno de los más competitivos entre los modelos evaluados, lo que sugiere que, aunque imperfecto, este enfoque representa una alternativa robusta cuando se busca un balance entre sensibilidad frente a comentarios negativos y una sólida capacidad de detección de positivos. A continuación, se presenta la matriz de confusión.

Figura 18

Matriz de confusión – Modelo LSTM

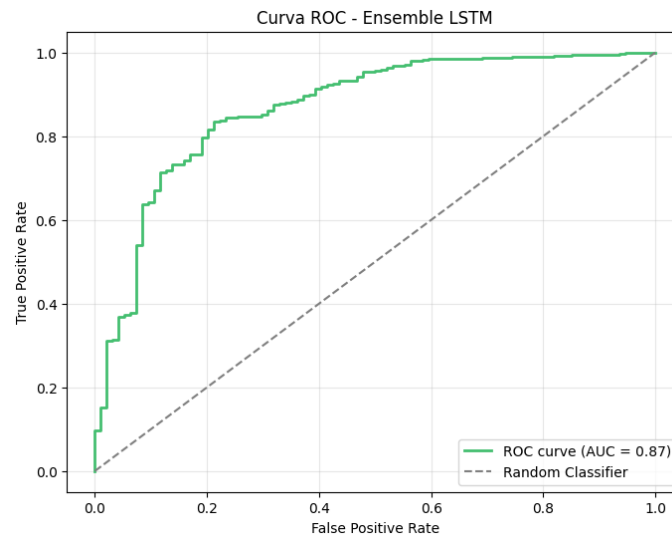


Fuente: Elaboración propia

La curva ROC del modelo Ensemble LSTM muestra un desempeño robusto con un área bajo la curva (AUC) de 0.87, lo cual indica una alta capacidad de discriminación entre las clases positiva y negativa. La curva se aleja notablemente de la línea diagonal (clasificador aleatorio), lo que evidencia que el modelo realiza predicciones significativamente mejores que el azar.

Figura 19

Curva ROC – Modelo LSTM



Fuente: Elaboración propia

Conclusiones y recomendaciones

Actualmente, los marketplaces no solo se han consolidado como canales clave para acceder a una amplia variedad de productos y servicios, sino que también han transformado significativamente el proceso de toma de decisiones de los compradores, teniendo en cuenta que permiten la posibilidad de consultar valoraciones y reseñas de otros usuarios. Esto reduce la incertidumbre y genera mayor confianza en los productos y en los vendedores. En plataformas como Mercado Libre, este sistema de retroalimentación no solo es útil para los consumidores, sino que también es una herramienta estratégica para los vendedores, ya que permite analizar cómo se posicionan sus marcas frente a la competencia, qué tan bien percibidos están sus productos y cómo evoluciona la experiencia del cliente a lo largo del tiempo.

Este estudio se enfocó en el segmento de calzado de descanso de Mercado Libre. En el análisis se observa que la mayoría de las reseñas reflejan una percepción positiva por parte de los usuarios: más del 75 % de los comentarios fueron acompañados de calificaciones de 5 estrellas y son comentarios cortos. Asimismo, se evidenció una fuerte asociación entre la satisfacción del cliente y factores como la comodidad, la suavidad y los materiales, en general, la calidad esperada del producto. Por su parte, los comentarios negativos, aunque minoritarios, se centran en la calidad, las tallas y discrepancias entre lo ofrecido y lo recibido. Adicionalmente, se evidenció que cerca del 30 % de los productos listados aún no han registrado ventas, lo cual podría estar relacionado con la falta de visibilidad, una mejor descripción del producto o diferenciación frente a la competencia. Esto resalta la importancia de las valoraciones como mecanismo de validación que permite influir en el posicionamiento de productos en entornos digitales altamente competitivos. Si bien muchos comentarios suelen tener una longitud corta, se observa que los negativos tienden a ser más extensos y detallados, lo que los convierte en una fuente valiosa de información para identificar oportunidades de mejora y comprender con mayor profundidad las expectativas de los consumidores.

Estos resultados también evidencian que los vendedores no solo pueden analizar el comportamiento de sus propios productos, sino que tienen la posibilidad de observar cuáles son los más vendidos entre otros competidores. Esto permitiría diseñar estrategias más amplias, no solo centradas en mejorar la calidad y el precio de su oferta actual, sino también en diversificar su catálogo. Pueden identificar qué tipos de calzado de descanso tienen mayor demanda, cuáles son los más comprados, qué marcas se destacan por sus ventas y cuáles reciben mejores recomendaciones. Además, pueden conocer qué aspectos valoran más los compradores, cuáles son sus principales quejas y qué elementos positivos destacan de los productos, lo que aporta información clave para mejorar su oferta.

Al utilizar modelos de Machine Learning, los dos modelos de redes neuronales demostraron ser estrategias efectivas para abordar el análisis automático de comentarios en el segmento de *calzado de descanso*, especialmente en un entorno marcado por el desbalance de clases (mayor porcentaje de comentarios positivos). El modelo CNN destacó por su capacidad para identificar todos los negativos (Recall 100 %), aunque con una precisión baja (0.41), lo que implica más falsos positivos. En contraste, el modelo LSTM ofreció un buen desempeño general (AUC 0.87) y un F1-score competitivo en la clase negativa (0.52). Ambos modelos son herramientas valiosas para monitorear reseñas y detectar posibles problemas de atención o calidad de forma automatizada.

La combinación de enfoques como CNN y LSTM con técnicas de *ensemble* y *undersampling* permitió una mejora en la detección de comentarios negativos, y también demostró el potencial de estas herramientas para ser incorporadas en sistemas automatizados de monitoreo de la experiencia del cliente. A futuro, este tipo de soluciones podrían integrarse directamente en las plataformas de e-commerce, permitiendo a los vendedores identificar patrones críticos de forma temprana y mejorar sus procesos de atención, logística o producto. Asimismo, abre la posibilidad de extender este análisis a otros segmentos e incluso conectar estos resultados con indicadores de desempeño comercial.

Uno de los principales desafíos enfrentados durante el desarrollo de la investigación fue el extremo desbalance en el conjunto de datos, con una proporción de casi 10 muestras positivas por cada negativa, esto llevó la investigación al camino de la combinación de diferentes técnicas para mitigar los efectos del desbalance durante el entrenamiento. A futuro, los resultados de esta investigación se podrían mejorar y robustecer mediante la adición de muestras negativas al conjunto de datos haciendo un targeting scrapping de la clase minoritaria o una implementación manual donde se enriquezca el abanico de reseñas negativas que permitan la obtención de modelos de machine learning balanceados.

Anexo 1. Descripción de herramientas, métricas y algoritmos utilizados

Categoría	Elemento	Descripción breve	Técnica esencial (explicada)
Librería	BeautifulSoup	Parseo de HTML para extraer datos durante el scraping	Lee el árbol HTML como un documento y permite buscar etiquetas o atributos con selectores (igual que inspeccionar en el navegador).
Librería	Selenium	Automatiza el navegador para páginas dinámicas	Abre un navegador real y ejecuta clics, scroll y teclado como un usuario; captura la página tal cual se renderiza.
Librería	pandas	Manipulación de datos tabulares (DataFrames)	Agrupar, filtra y calcula sobre tablas en memoria usando operaciones vectorizadas.
Librería	NumPy	Cálculo numérico con matrices	Representa datos como grandes arreglos en C y realiza álgebra lineal de forma eficiente.
Librería	NLTK	Tokenización, lematización, stop-words	Aplica reglas lingüísticas y diccionarios para limpiar y normalizar texto (quitar stop-words, lematizar, etc.).
Librería	spaCy	Pipeline NLP con modelos estadísticos	Carga modelos pre-entrenados que identifican lemas, entidades y dependencias usando redes neuronales ligeras.
Librería	scikit-learn	Algoritmos ML y métricas	Ofrece una interfaz uniforme amigable fit/predict para utilizar más de 100 algoritmos clásicos de ML.
Librería	TensorFlow / Keras	Redes neuronales profundas	Permite definir redes neuronales como bloques de capas, calcula automáticamente los gradientes para ajustar los pesos y acelera el entrenamiento usando CPU o GPU.
Librería	PyTorch	Deep learning	Crea tensores y registra automáticamente las operaciones para calcular gradientes sobre la marcha, ideal para prototipar.
Métrica	Accuracy	% de predicciones correctas	Cuenta cuántas respuestas acertó el modelo sobre el total de casos.

Métrica	Precision (positivo)	Calidad de los positivos predichos	De los casos que el modelo marcó como positivos, qué porcentaje fue correcto (evita falsos positivos).
Métrica	Recall (positivo)	Cobertura de los positivos reales	De todos los positivos reales, cuántos detectó el modelo (evita falsos negativos).
Métrica	F1-score	Balance entre Precision y Recall	Media armónica de Precision y Recall; útil cuando las clases están desbalanceadas.
Métrica	ROC AUC	Área bajo la curva ROC	Evalúa la capacidad del modelo para separar clases a cualquier umbral (1 = perfecto, 0.5 = azar).
Algoritmo	CNN Ensemble	Conjunto de CNN 1D para texto	Detecta patrones locales (n-gramas) con filtros convolucionales; combina varios modelos para reducir el error.
Algoritmo	LSTM Ensemble	Conjunto de redes LSTM	Lee la frase secuencialmente y recuerda información relevante mediante puertas de memoria; promedia varios modelos.
Algoritmo	BiLSTM Ensemble	LSTM bidireccional	Procesa la oración de izquierda a derecha y derecha a izquierda para capturar contexto completo, luego combina varios modelos.
Algoritmo	BERT-BETO	Transformer en español fine-tuned	Analiza la relación de todas las palabras simultáneamente mediante auto-atención; se ajusta a los datos para clasificar sentimiento.
Algoritmo	MLP	Perceptrón multicapa	Capas densas totalmente conectadas que aprenden pesos con retro-propagación sobre vectores de características.
Muestreo	Undersampling	Reduce la clase mayoritaria	Elimina aleatoriamente ejemplos de la clase dominante para equilibrar el conjunto y evitar sesgo.
Muestreo	Oversampling	Aumenta la clase minoritaria	Copia o sintetiza ejemplos nuevos para igualar el número de instancias por clase.

Referencias

- Asociación Española de la Economía Digital. (2012). *Libro blanco del comercio electrónico*. Madrid: Secretaría de Estado de Telecomunicaciones de España.
- Cortés Díaz, N. S. (2021). Uso del análisis de sentimientos para medir el posicionamiento de una marca a través de la información extraída de la plataforma twitter [Anteproyecto enviado en cumplimiento del requisito parcial para optar por el grado de Ingeniería Electrónica, Universidad Santo Tomás]. <https://repository.usta.edu.co/items/bbc66e54-0596-443b-bd92-0f1591c710a2>
- Cumming, D., Johan, S., Khan, Z., & Meyer, M. (2023). E-Commerce Policy and International Business. *Management International Review*, 63, 3–25. <https://link.springer.com/article/10.1007/s11575-022-00489-8>
- Daza, A., Rueda, N. D. G., Sánchez, M. S. A., Espíritu, W. F. R., & Quiñones, M. E. C. (2024). Sentiment Analysis on E-Commerce Product Reviews Using Machine Learning and Deep Learning Algorithms: A Bibliometric Analysis and Systematic Literature Review, Challenges and Future Works. *International Journal of Information Management Data Insights*, 4(2), 100267. <https://doi.org/10.1016/j.ijime.2024.100267>
- Elastic. (s.f.). *¿Qué es el análisis de sentimiento?* Elastic. <https://www.elastic.co/es/what-is/sentiment-analysis>
- Espitaleta, J. A., Maza, J. G., & García, K. P. (2022). *Análisis de sentimientos de reseñas para determinar la acogida de un producto utilizando técnicas de machine learning y data mining*. [Artículo, Universidad del Norte]. <https://manglar.uninorte.edu.co/handle/10584/11237?show=full>

- Geetha, M. P., & Renuka, D. K. (2021). Improving the performance of aspect based sentiment analysis using fine-tuned Bert Base Uncased model. *International Journal of Intelligent Networks*, 2, 64-69. <https://doi.org/10.1016/j.ijin.2021.06.005>
- Harunasir, M. F., Palanichamy, N., Haw, S. C., & Ng, K. W. (2023). Sentiment analysis of amazon product reviews by supervised machine learning models. *Journal of Advances in Information Technology*, 14(4), 857-862. doi: 10.12720/jait.14.4.857-862
- Hernández Sampieri, R., Mendoza Torres, C. P., & Fernández Collado, C. (2021). *Metodología de la investigación* (6.^a ed.). McGraw-Hill Education.
- Jain, S. M. (2022). Introduction to Transformers for NLP (1st ed.). Apress Berkeley, CA. <https://doi.org/10.1007/978-1-4842-8844-3>
- Kamath, U., Liu, J., & Whitaker, J. (2019). Deep Learning for NLP and Speech Recognition (1st ed.). Springer Cham. <https://doi.org/10.1007/978-3-030-14596-5>
- Kaur, P. (2022). Sentiment analysis using web scraping for live news data with machine learning algorithms. *Materials today: proceedings*, 65, 3333-3341. <https://doi.org/10.1016/j.matpr.2022.05.409>
- Mercado Libre. (2024, octubre). Mercado Libre consolida su liderazgo en Retail Media en Argentina y la región. <https://news.mercadolibre.com/retail-media-ads-2024>
- Peña Garcia, N., Lozada Otalora, M., Pérez Auza, D., & Cruz, M. P. (2024). Reviews, trust, and customer experience in online marketplaces: the case of Mercado Libre Colombia. *Frontiers in Communication*, 9, 1-14. <https://doi.org/10.3389/fcomm.2024.1460321>
- Pérez, M. (2021, 10 de febrero). Los colombianos caminaron en 'chanclas' durante el 2020. *Portafolio*. https://www.portafolio.co/negocios/los-colombianos-caminaron-en-chanclas-durante-el-2020-549023?utm_source=chatgpt.com

- Petrlik Azabache, I. C., Carranza Barrena, W., Torres Talaverano, L. E., & Coveñas Lalupu, J. (2024, Junio 22). Aplicación de la minería de datos en el marketing usando el análisis de sentimientos de los clientes e-commerce. *Campus*, 29 (37), 167-194. <https://portalrevistas.aulavirtualusmp.pe/index.php/rc/article/view/2855>
- Ryali, N., Manne, N., Ravisankar, A., Tripathi, M. A., Tripathi, R., & Naresh, M. V. (2024, Marzo 12). Stage by stage E-Ecommerce market database analysis by using machine learning models. *EAI Endorsed Transactions on Internet of Things*, 10. 1-7. <https://doi.org/10.4108/eetiot.5383>
- Saraswat, A., Kumar Azad, H., & Abhishek, K. (2022). Towards improving e-commerce customer review analysis for sentiment detection. *Scientific Reports*, 12(1): 1-15. <https://doi.org/10.1038/s41598-022-26432-3>
- Stephen, A. T., & Toubia, O. (2010). Deriving Value from Social Commerce Networks. *Journal of Marketing Research*, 47(2), 215-228. <https://doi.org/10.1509/jmkr.47.2.215>
- Vargas, B. H. (2020). *Impacto del retail online en Colombia*. [Trabajo de especialización, Universidad Militar Nueva Granada]. <https://repository.unimilitar.edu.co/items/e2ba7f04-79ea-4b0e-b1b6-5e3acad9159a>
- Vij, S. & Kaur, B. (2024), Measuring consumer perceptions towards S-commerce: scale development and validation. *Rajagiri Management Journal*. <https://doi.org/10.1108/RAMJ-06-2024-01664>
- Zhang, X., Guo, F., Chen, T., & Pan, L. (2023, Diciembre 4). A Brief Survey of Machine Learning and Deep Learning Techniques for E-Commerce Research. *Journal of Theoretical and Applied Electronic Commerce Research*, 18 (4), 2188- 2216. <https://doi.org/10.3390/jtaer18040110>